

Come descrivere un Linguaggio di Programmazione

Sommario: 2 marzo, 2016

- Sintassi, Semantica, Pragmatica e Implementazione
- Grammatiche e Sintassi
- Grammatiche Context Free: Derivazione, Alberi, Ambiguità
- Sintassi: Proprietà contestuali
- Compilatore: Le fasi di analisi sintattica, semantica e di generazione del codice
- Semantica: Formalismi
- Semantica operativa strutturata: Stato, Transizione, Computazione.

- Un programma si presenta come una "lunga" sequenza di caratteri che rappresentano simboli e strutture del linguaggio con cui il programma è espresso.

```
#include<stdio.h> #include<stdlib.h> voidXSwap(intA[], intB[]){A[0] = ...
```

- **Lessico.** La definizione di come e quali sequenze di caratteri formano simboli (inclusi i separatori di simboli) affidata al Lessico.
- **Sintassi.** La definizione di come e quali sequenze di simboli formano costrutti e la struttura del programma affidata alla Sintassi.

- **Grammatiche.** Lessico e Sintassi possono essere completamente definite mediante grammatiche:
 - Lineari, per il lessico, $\mathcal{G}^{\mathcal{R}}$.
 - Libere da contesto (Context Free), per la sintassi, $\mathcal{G}^{\mathcal{F}}$.
 - $\mathcal{G}^{\mathcal{R}} \subset \mathcal{G}^{\mathcal{F}}$.
- Sia A insieme finito di simboli (caratteri):
 - A^* insieme di tutte le sequenze finite di simboli su A .
 - A^* è chiuso rispetto all'operatore binario, associativo, \dots , chiamato *giustapposizione*¹: esempio $\text{Pi.sa} = \text{Pisa}$.
 - $\epsilon \in A^*$ seq. vuota: $\epsilon.q = q = q.\epsilon, \forall q \in A^*$

Definition (Linguaggio (formale) su A)

Un linguaggio (formale) su A è un sottoinsieme di A^*

¹ la sua notazione è omessa quando non vi è ambiguità

Definition (Grammatica Libera)

Una grammatica libera è una quadrupla (NT, T, R, S) tale che:

- **NT** insieme finito dei non terminali.
- **T** insieme finito dei terminali.
- **S** simbolo iniziale, $S \in NT$.
- **R** insieme finito delle produzioni,

$$R \equiv \{V_i \rightarrow w_i \mid w_i \in (T \cup NT)^*, i \in [1, k]\}$$

Esempio

$$G = (\{E\}, \{I, +, *, (,)\}, E, R)$$

$$R = \{E \rightarrow E + E, E \rightarrow E * E, E \rightarrow I, E \rightarrow (E)\}$$

Notazione. $V \rightarrow \alpha_1 | \dots | \alpha_k$ invece di $V_1 \rightarrow \alpha_1, \dots, V_k \rightarrow \alpha_k$ quando, $V = V_1 = \dots = V_k$.

Esempio

$$R = \{E \rightarrow E + E \mid E * E \mid I \mid (E)\}$$

Esempio

$$G = (\{E\}, \{I, +, *, (,)\}, E, R)$$

$$R = \{E \rightarrow E + E, E \rightarrow E * E, E \rightarrow I, E \rightarrow (E)\}$$

Qual'è il significato di G ? ²

Definition (La relazione \Rightarrow)

Ogni grammatica libera $G \equiv (NT, T, R, S)$ definisce una relazione binaria \Rightarrow_G (o, semplicemente \Rightarrow) su $(T \cup NT)^*$ tale che:

$$\forall \alpha.V.\rho, \alpha.\gamma.\rho \in (T \cup NT)^*, \alpha V \rho \Rightarrow \alpha \gamma \rho \text{ sse } V \rightarrow \gamma \in R$$

Definition (Linguaggio generato)

Sia $G \equiv (NT, T, R, S)$ libera. Il linguaggio definito da G :

$$\mathcal{L}(G) = \{\alpha \in T^* \mid S \Rightarrow^* \alpha\}$$

dove, \Rightarrow^* è la chiusura transitiva (e riflessiva) di \Rightarrow_G

² "sse" sta per "se e solo se"

Definition (Derivazione)

Sia $G \equiv (NT, T, R, S)$ libera. Siano $v, w \in (T \cup NT)^*$. Sia $v \Rightarrow^* w$. Una derivazione, in G , da v a w , è una sequenza $v \Rightarrow w_0 \Rightarrow w_1 \Rightarrow \dots \Rightarrow w$

Esempio

La derivazione ci fornisce una prova di appartenenza. Si dimostri che $I * I + I \in \mathcal{L}(G)$.

$$G = (\{E\}, \{I, +, *\}, E, R)$$

$$R = \{E \rightarrow E + E, E \rightarrow E * E, E \rightarrow I, E \rightarrow (E)\}$$

Procediamo applicando una \Rightarrow alla volta a partire da E

$$E \Rightarrow_2 E * E^3$$

$$\Rightarrow_3 I * E$$

$$\Rightarrow_1 I * E + E$$

$$\Rightarrow_3 I * I + E$$

$$\Rightarrow_3 I * I + I$$

Aggiungendo induzione possiamo dimostrare che:

$$\{I.\alpha_1.\dots.\alpha_n \mid \alpha_i \in \{+I, *I\}, n \geq 0\} \subset \mathcal{L}(G).$$

³Un pedice può indicare la produzione usata. In questo caso, usiamo la posizione a partire da 1 per la produzione più a sinistra

Esempio

$$G = (\{E\}, \{I, +, *, (,)\}, E, R)$$

$$R = \{E \rightarrow E + E, E \rightarrow E * E, E \rightarrow I, E \rightarrow (E)\}$$

- La \Rightarrow su sequenze di simboli (stringhe) grammaticali ci dice proprio tutto?

$$E \Rightarrow_2 E * E \Rightarrow_3 I * E \Rightarrow_1 I * E + E \Rightarrow_3 I * I + E \Rightarrow_3 I * I + I$$

$$E \Rightarrow_2 E * E \Rightarrow_1 E * E + E \Rightarrow_3 I * E + E \Rightarrow_3 I * I + E \Rightarrow_3 I * I + I$$

$$E \Rightarrow_1 E + E \Rightarrow_2 E * E + E \Rightarrow_3 I * E + E \Rightarrow_3 I * I + E \Rightarrow_3 I * I + I$$

- In realtà NO.
 - 2 delle 3 derivazioni sopra ci dicono la stessa cosa, 1 dice una cosa.
 - Quali? In cosa, sono diverse?
 - Useremo la struttura degli alberi per rispondere.
- La sequenza di simboli grammaticali non è abbastanza espressiva

Definition

- $[] \in \text{Tree}^A$
- $[a - (t_1, \dots, t_n)] \in \text{Tree}^A$, per $a \in A, t_i \in \text{Tree}^A, n \geq 0$

Notazione. $[a - ()]$ può essere scritto $[a]$.

- Gli alberi possono essere utilizzati come relazioni sulla struttura di un termine
 - Ogni arco è una coppia della relazione *sottotermine*
- Hanno una rappresentazione grafica.
 - mostriamo quella di $[E - ([E],[+],[E])]$

Definition (La relazione $\Rightarrow^{\text{Tree}}$)

Ogni grammatica libera $G \equiv (NT, T, R, S)$ definisce una relazione binaria $\Rightarrow_G^{\text{Tree}}$ (o, semplicemente $\Rightarrow^{\text{Tree}}$, ovvero \Rightarrow) su $\text{Tree}^{\text{TUNT}}$ tale che:

- $[V] \Rightarrow [V - ([u_1], \dots, [u_n])]$
sse $V \rightarrow u_1 \dots u_n \in R$ and $u_i \in (T \cup NT)$
- $[V - (t_1, \dots, t_j, \dots, t_n)] \Rightarrow [V - (t_1, \dots, r_j, \dots, t_n)]$
sse $1 \leq j \leq n \wedge (\forall i) t_i \in \text{Tree}^{\text{TUNT}} \wedge t_j \Rightarrow r_j$

Definition (Linguaggio generato su $\text{Tree}^{\text{TUNT}}$ - Parse Tree set)

Sia $G \equiv (NT, T, R, S)$ libera. Il linguaggio definito da G :

$$\mathcal{L}(G) = \{\alpha \in \text{Tree}^{\text{TUNT}} \mid [S] \Rightarrow^* \alpha\}$$

dove, \Rightarrow^* è la chiusura transitiva (e riflessiva) di \Rightarrow

Definition (Derivazione su $\text{Tree}^{\text{TUNT}}$)

Sia $G \equiv (\text{NT}, \text{T}, \text{R}, \text{S})$ libera. Siano $u, q \in \text{Tree}^{\text{TUNT}}$. Sia $u \Rightarrow^* q$.
Una derivazione, in G , da u a q , è una sequenza
 $u \Rightarrow q_0 \Rightarrow q_1 \Rightarrow \dots \Rightarrow q$

Esempio

$$G = (\{E\}, \{I, +, *, (,)\}, E, R)$$

$$R = \{E \rightarrow E + E, E \rightarrow E * E, E \rightarrow I, E \rightarrow (E)\}$$

- La \Rightarrow su stringhe ci dice proprio tutto?

$$E \Rightarrow_2 E * E \Rightarrow_3 I * E \Rightarrow_1 I * E + E \Rightarrow_3 I * I + E \Rightarrow_3 I * I + I$$

$$E \Rightarrow_2 E * E \Rightarrow_1 E * E + E \Rightarrow_3 I * E + E \Rightarrow_3 I * I + E \Rightarrow_3 I * I + I$$

$$E \Rightarrow_1 E + E \Rightarrow_2 E * E + E \Rightarrow_3 I * E + E \Rightarrow_3 I * I + E \Rightarrow_3 I * I + I$$

- La \Rightarrow su alberi?

$$\begin{aligned} [E] &\Rightarrow_2 [E - ([E], [*, [E]])] \Rightarrow_3 [E - ([E - ([I]), [*, [E]])] \\ &\Rightarrow^* [E - ([E - ([I]), [*, [E - ([E - ([I]), [+], [E - ([I])]])])] \end{aligned}$$

$$[E] \Rightarrow^* \dots$$

$$[E] \Rightarrow_1 [E - ([E], [+], [E])] \Rightarrow_2 [E - ([E - ([E], [*, [E]), [+], [E]])]$$

$$\Rightarrow^* [E - ([E - ([E - ([I]), [*, [E - ([I])]])], [+], [E - ([I])]])]$$

La relazione \Rightarrow su alberi: Una vista grafica

Esempio

- La \Rightarrow su alberi?

$$\begin{aligned} [E] &\Rightarrow_2 [E - ([E], [*], [E])] \Rightarrow_3 [E - ([E - ([I])], [*], [E])] \\ &\Rightarrow^* [E - ([E - ([I])], [*], [E - ([E - ([I])], [+], [E - ([I])]])] \end{aligned}$$

$[E] \Rightarrow^* \dots$

$$\begin{aligned} [E] &\Rightarrow_1 [E - ([E], [+], [E])] \Rightarrow_2 [E - ([E - ([E], [*], [E]), [+], [E])] \\ &\Rightarrow^* [E - ([E - ([E - ([I])], [*], [E - ([I])]), [+], [E - ([I])])] \end{aligned}$$

Definition (Albero di derivazione sintattica o Parse Tree)

Sia $G \equiv (NT, T, R, S)$ libera. Sia $Q_G = \{q \in \text{Tree}^{\text{TUNT}} \mid [S] \Rightarrow^* q\}$.
 Q_G è l'insieme di tutti e soli gli alberi di derivazione sintattica, detti anche, parse tree, di G .

Definition (Frontiera di un albero /1)

La frontiera di un albero $q \in \text{Tree}^A$ è una stringa di A^* , ovvero $\text{fron}(q) \in A^*$ per ogni q , così definita:

- $\text{fron}([\])$ = ϵ
- $\text{fron}([a])$ = a
- $\text{fron}([a - (t_1, \dots, t_n)])$ = $\text{fron}(t_1) \dots \text{fron}(t_n)$, $n > 0$

Definition (Frontiera di un albero)

La frontiera di un albero $q \in \text{Tree}^A$ è una stringa di A^* , ovvero $\text{fron}(q) \in A^*$ per ogni q , così definita:

- $\text{fron}([\])=\epsilon$
- $\text{fron}([a])=a$
- $\text{fron}([a - (t_1, \dots, t_n)]) = \text{fron}(t_1) \dots \text{fron}(t_n), \quad n > 0$

Esempio

$$\begin{aligned} \text{fron}([E - ([E - ([I]), [*], [E - ([E - ([I]), [+], [E - ([I])])])])]) &= \\ &= \text{fron}([E - ([I])].\text{fron}([*]).\text{fron}([E - ([E - ([I]), [+], [E - ([I])])])]) \\ &= \text{fron}([I]).\text{fron}([*]).\text{fron}([E - ([I])].\text{fron}([+]).\text{fron}([E - ([I])])]) \\ &= \text{fron}([I]).\text{fron}([*]).\text{fron}([I]).\text{fron}([+]).\text{fron}([I]) \\ &= I \cdot * \cdot I \cdot + \cdot I = I * I + I \end{aligned}$$

Definition (Linguaggio generato utilizzando Parse Tree)

Sia $G \equiv (NT, T, R, S)$ libera. Il linguaggio definito da G :

$$\mathcal{L}(G) = \{\text{fron}(q) \in T^* \mid [S] \Rightarrow^* q\}$$

dove, \Rightarrow^* è la chiusura transitiva (e riflessiva) di $\Rightarrow_G^{\text{Tree}^{\text{TUNT}}}$

Definition (Grammatica Ambigua)

$G \equiv (NT, T, R, S)$ è ambigua se $\exists q_1 \neq q_2 \in \text{Tree}^{\text{TUNT}}$:

- $[S] \Rightarrow^* q_1, [S] \Rightarrow^* q_2$
- $\text{fron}([q_1]) = \text{fron}([q_2]) \in T^*$

- La **sintassi di un LP** deve essere espressa mediante una grammatica libera **non ambigua**
- Ogni **termine** di LP deve avere **un'unica struttura sintattica** che ne mostra i sottotermini componenti

Esempio Grammatica Ambigua

$$G = (\{E\}, \{I, +, *\}, E, R)$$

$$R = \{E \rightarrow E + E, E \rightarrow E * E, E \rightarrow I, E \rightarrow (E)\}$$

Esempio Grammatica non Ambigua

$$G' = (\{E, F, T\}, \{I, +, *\}, E, R')$$

$$R' = \{E \rightarrow E + F \mid F$$

$$F \rightarrow F * T \mid T$$

$$T \rightarrow I \mid (E)\}$$

$$\mathcal{L}(G) = \mathcal{L}(G')$$

- Lessico e Sintassi si integrano nella definizione di un Linguaggio

Esempio sottoLinguaggio delle Espressioni Aritmetiche

Sintassi: Espressione

$$G = (\{E, F, T\}, \{N, +, -, *\}, E, R_G)$$

$$R_G = \{ E \rightarrow E + F \mid F$$

$$F \rightarrow F * T \mid T$$

$$T \rightarrow -T \mid N \mid (E) \}$$

Lessico: Naturale (Identificatore)

$$H = (\{L, N, D\}, \{-, +, *, 0, \dots, 9\}, L, R_H)$$

$$R_H = \{ L \rightarrow N \mid * \mid - \mid +$$

$$N \rightarrow D N \mid D$$

$$D \rightarrow 0 \mid 1 \mid \dots \mid 9 \}$$

Riconosciamo la stringa, $13*-5+007 \in \mathcal{L}(\langle G, H \rangle)$.

● Esercizio 2.10.1

- (a) Si completi la definizione di una grammatica le cui produzioni sono sotto.
(b) Si mostri che la grammatica ottenuta è ambigua.

$$\begin{aligned} E &\rightarrow T \mid T + E \mid T - E \\ T &\rightarrow A \mid A * E \end{aligned}$$

Soluzione

- (a) $G = \dots$
(b) Consideriamo la stringa: $s = \dots$

Mostriamo che esistono due diversi parse tree aventi s come frontiera.

- **Esercizio 2.10.4**

Si dia una grammatica non ambigua che generi tutte e sole le sequenze di parentesi angolate bilanciate

Soluzione

Definiamo $G = (\{<, >\}, \{S, B\}, S, R_G)$, dove:

$R_G = \{\dots\}$

● Esercizio 2.10.5

Si chiama *lineare* una grammatica le cui produzioni hanno la forma $A \rightarrow t B$ oppure $A \rightarrow t$, dove A, B siano non terminali e t sia un terminale o ϵ . Un linguaggio che può essere espresso con una grammatica lineare si chiama *regolare* e può essere riconosciuto da un automa a stati finiti. Si mostri che il linguaggio $L = \{a^n b^m \mid n, m \geq 1\}$ è regolare.

Soluzione

Definiamo $G = (\{a, b\}, \{S, B\}, S, R_G)$, dove:
 $R_G = \{\dots\}$

- **Esercizio 2.10.5bis**

Si dia una grammatica non ambigua per che il linguaggio $L = \{a^n b^m \mid n \leq m\}$.

Soluzione

Definiamo $G = (\{a, b\}, \{S, B\}, S, R_G)$, dove:

$R_G = \{\dots\}$

● Parse Tree in C

Si dia, in C, una implementazione per Parse Tree di una grammatica. In particolare si forniscano:

- (a) una rappresentazione per tali alberi;
- (b) le operazioni per manipolare tali alberi in accordo alla relazione deriva.

Soluzione

- (a) Dobbiamo fornire definizioni struct adeguate.
- (b) Dobbiamo includere un'operazione:

$\text{Replace}(t,p,s,t')$ che se l'albero t al cammino p ha un nodo foglia e questo nodo è etichettato s , allora modifica t sostituendo la foglia al cammino p con l'albero t' . In caso contrario segnala una "anomalia".

$\text{Find}(t,s)$ che visita l'albero t alla ricerca di una foglia etichettata s . Produce un cammino p ad una tale foglia o altrimenti un cammino vuoto.

E poi abbiamo bisogno di valori per rappresentare ... e operazioni su tali valori